

Post-Earthquake Building Damage State Classification Using Machine Learning: The Case of İzmir

Derya Yalçın¹ , Bahadır Aktuğ² 

¹ Disaster and Emergency Management Authority (AFAD), 06800 Ankara, Türkiye

² Ankara University, Department of Geophysical Engineering, 06830 Ankara, Türkiye

Keywords

Damage estimation, Machine learning, Samos Island (Seferihisar–İzmir) earthquake, Unbalanced dataset, Geographic Information Systems (GIS)

Highlights

- * Comparison of damage estimation performance across different machine learning algorithms
- * Estimation of building damage states using real damage data
- * Creating a spatial damage estimation map in GIS using machine learning methods

Aim

To estimate post-earthquake building damage using machine learning and GIS

Location

Bayraklı and Bornova districts, İzmir, Türkiye

Methods

Machine learning algorithms (RF, DT, XGB, SVM, ANN) applied to post-earthquake damage data; class imbalance corrected using ROS and SMOTE

Results

Ensemble-based models provide more reliable post-earthquake damage estimation

Supporting Institutions

Data provided by AFAD and İzmir Metropolitan Municipality

Financial Disclosure

The authors declared that this study has received no financial support

Peer-review

Externally peer-reviewed

Conflict of Interest

The authors have no conflicts of interest to declare

How to cite

Yalçın D., Aktuğ B., 2026. Post-Earthquake Building Damage State Classification Using Machine Learning: The Case of İzmir, Turk Deprem Arastirma Dergisi, 8(1), 92-103, DOI:10.46464/tdad.1802507.

Manuscript

Research Article

Received: 13.10.2025

Revised: 15.01.2026

Accepted: 03.02.2026

Printed: 30.04.2026

DOI

10.46464/tdad.1802507



Content of this journal is licensed under a Creative Commons Attribution 4.0 International Non-Commercial License

Corresponding Author

Derya Yalçın

Email: derya.yalcin@afad.gov.tr

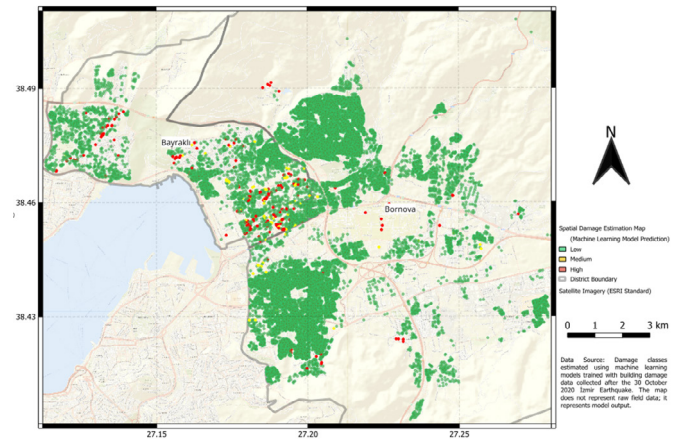


Figure
Spatial Damage Estimation Map

Makine Öğrenmesi Yöntemleri ile Deprem Sonrası Bina Hasar Sınıfı Kestirimi: İzmir Örneği

Derya Yalçın ¹, Bahadır Aktuğ ²

¹ Afet ve Acil Durum Yönetimi Başkanlığı (AFAD), 06800 Ankara, Türkiye
² Ankara Üniversitesi, Jeofizik Mühendisliği Bölümü, 06830 Ankara, Türkiye

ÖZET

Bu çalışmada, 30 Ekim 2020 Sisam Adası (Seferihisar-İzmir) depremi sonrasında Bayraklı ve Bornova ilçelerinde saha gözlemlerine dayalı olarak belirlenen bina hasar sınıflarının, makine öğrenmesi yöntemleriyle tahmin edilmesi amaçlanmıştır. Düşük, orta ve yüksek olmak üzere üç hasar sınıfından oluşan veri seti, belirgin sınıf dengesizliği içermektedir. Bu nedenle model performansları, dengesiz veri setlerine duyarlı ölçütler kullanılarak değerlendirilmiştir. Karar ağacı (DT), rastgele orman (RF), yapay sinir ağları (ANN), destek vektör makineleri (SVM) ve Aşırı Gradyan Artırma Algoritması (XGBoost), algoritmaları karşılaştırmalı olarak analiz edilmiştir. En iyi performansı sağlayan modelin çıktıları Coğrafi Bilgi Sistemleri ortamına aktarılmış ve mekânsal hasar kestirim haritası üretilmiştir. Elde edilen bulgular, makine öğrenmesi yöntemlerinin deprem sonrası bina hasarlarının mekânsal örüntülerini modellemede etkili bir araç sunduğunu göstermektedir.

Anahtar Kelimeler

Hasar kestirimi, Makine öğrenmesi, Sisam Adası (Seferihisar-İzmir) depremi, Dengesiz veri seti, Coğrafi Bilgi Sistemleri (CBS)

Öne Çıkanlar

- * Farklı makine öğrenmesi algoritmalarının hasar kestirim performanslarının karşılaştırılması
- * Gerçek hasar verileriyle bina hasar durumu kestiriminin yapılması
- * Makine öğrenmesi yöntemleri modeli ile CBS ortamında mekânsal hasar kestirim haritası oluşturulması

Makale

Araştırma Makalesi

Geliş: 13.10.2025
Düzeltilme: 15.01.2026
Kabul: 03.02.2026
Basım: 30.04.2026

DOI

10.46464/tdad.1802507

Sorumlu yazar

Derya Yalçın
E-posta:
derya.yalcin@afad.gov.tr

Post-Earthquake Building Damage State Classification Using Machine Learning: The Case of İzmir

Derya Yalçın ¹, Bahadır Aktuğ ²

¹ Disaster and Emergency Management Authority (AFAD), 06800 Ankara, Türkiye
² Ankara University, Department of Geophysical Engineering, 06830 Ankara, Türkiye

ABSTRACT

This study aims to estimate post-earthquake building damage classes in the Bayraklı and Bornova districts of İzmir following the 30 October 2020 Samos Island (Seferihisar-İzmir) earthquake using machine learning methods. The dataset consists of three damage classes (low, moderate, and high) derived from field-based damage assessments and exhibits a severe class imbalance. Therefore, model performances were evaluated using class-sensitive metrics. Decision Tree, Random Forest, Artificial Neural Networks, Support Vector Machines, and Extreme Gradient Boosting (XGBoost) algorithms were comparatively analyzed. The outputs of the best-performing model were transferred to a Geographic Information Systems environment to generate building-scale spatial damage estimation maps. The results demonstrate that machine learning-based approaches provide an effective framework for capturing spatial patterns of post-earthquake building damage and supporting risk-informed decision-making processes.

Keywords

Damage estimation, Machine learning, Samos Island (Seferihisar-İzmir) earthquake, Unbalanced dataset, Geographic Information Systems (GIS)

Highlights

- * Comparison of damage estimation performance across different machine learning algorithms
- * Estimation of building damage states using real damage data
- * Creating a spatial damage estimation map in GIS using machine learning methods

Manuscript

Research Article

Received: 13.10.2025
Revised: 15.01.2026
Accepted: 03.02.2026
Printed: 30.04.2026

DOI

10.46464/tdad.1802507

Corresponding Author

Derya Yalçın
Email:
derya.yalcin@afad.gov.tr

1. GİRİŞ

Depremler, dünya genelinde en yıkıcı doğa kaynaklı tehlikeler arasında yer almakta ve özellikle aktif tektonik kuşaklarda bulunan ülkelerde ciddi can ve mal kayıplarına neden olmaktadır. Türkiye, Alp-Himalaya orojenik kuşağı üzerinde yer alması nedeniyle yüksek sismisiteye sahip olup; 1999 Marmara, 2011 Van ve 2020 İzmir depremleri gibi büyük ölçekli afetler, mevcut yapı stokunun kırılma eğilimini açık biçimde ortaya koymuştur (Erdik 2013, Şengör ve diğ. 2014, Seyitoğlu ve diğ. 2022). Özellikle İzmir, yoğun kentleşme, eski yapı stoku ve zayıf zemin koşulları nedeniyle deprem riski yüksek kentlerden biridir (Aktuğ ve diğ. 2021, Çetin ve diğ. 2021).

6 Şubat 2023 tarihinde meydana gelen Kahramanmaraş merkezli depremler (Mw 7.7 ve Mw 7.6), Türkiye Cumhuriyeti tarihinin en yıkıcı afetleri arasında yer almıştır. AFAD (2023) raporuna göre, iki ana şok ve çok sayıda artçı deprem sonucunda 11 ilde geniş çaplı yıkım meydana gelmiş ve 50 binden fazla kişi hayatını kaybetmiştir. Bu depremler, özellikle yetersiz mühendislik uygulamaları, zayıf zemin koşulları ve eski yapı stokunun sismik açıdan yüksek risk taşıdığını bir kez daha göstermiştir. Söz konusu afetler, yapı stokunun sismik performansının doğru biçimde değerlendirilebilmesi için veri temelli yaklaşımların ve makine öğrenmesi yöntemlerinin afet yönetimi süreçlerine entegrasyonunun gerekliliğini açık biçimde ortaya koymuştur.

Deprem risk yönetiminde en kritik aşamalardan biri, mevcut yapı stokunun sismik kırılma eğiliminin değerlendirilmesidir. Geleneksel kırılma eğilimi analizleri; saha gözlemleri, mühendislik hesapları ve analitik modeller üzerine kurulmakta olup (Kappos ve diğ. 2006, FEMA 2012), geniş ölçekli uygulamalarda yüksek maliyet ve zaman gereksinimi nedeniyle sınırlı kalabilmektedir. Bu durum, özellikle büyük kentlerde hızlı ve bütüncül değerlendirme yapabilen yeni yöntemlere olan ihtiyacı artırmaktadır.

Son yıllarda makine öğrenmesi (ML) yöntemleri, deprem mühendisliği alanında güçlü tahmin araçları olarak öne çıkmaktadır (Xie ve diğ. 2020). Makine öğrenmesi yöntemlerinin sismik kırılma eğilimi, hasar tahmini ve risk değerlendirme çalışmalarındaki uygulamalarını kapsamlı biçimde ele alan derleme çalışmaları, bu yaklaşımların özellikle büyük ölçekli ve karmaşık veri setlerinde önemli avantajlar sunduğunu ortaya koymaktadır (Xie ve diğ. 2020). Random Forest (Breiman 2001), Decision Tree (Quinlan 1993), Extreme Gradient Boosting (Chen ve Guestrin 2016), Yapay Sinir Ağları (Rumelhart ve diğ. 1986, Zhu ve diğ. 2020) ve Destek Vektör Makineleri (Cortes ve Vapnik 1995) gibi algoritmalar, bina hasar tahmini (Onat ve diğ. 2022), kırılma eğilimi modellemesi (Khosravani ve diğ. 2021) ve sismik risk değerlendirme çalışmalarında yaygın olarak kullanılmaktadır. Bu çalışmalar, makine öğrenmesi yöntemlerinin deprem hasar tahmininde yüksek potansiyele sahip olduğunu göstermektedir. Ancak, büyük ölçekli ve aşırı dengesiz gerçek hasar veri setleri üzerinde, farklı ML algoritmalarının performanslarının sistematik biçimde karşılaştırıldığı çalışmalar sınırlıdır.

Bu çalışmada kullanılan bina hasar verileri, gerçekleşmiş bir deprem sonrasında saha gözlemlerine dayalı olarak elde edilmiştir. Bu nedenle çalışmada kullanılan "kırılma eğilimi" kavramı, klasik senaryo tabanlı kapasite-talep ilişkilerine

dayalı kırılma eğilimlerinden farklı olarak, deprem sonrası gözlenen bina hasar sınıfını temsil eden bir gösterge değişken olarak ele alınmaktadır. Dolayısıyla çalışma, senaryo temelli kırılma eğilimi analizi değil; gerçek deprem verilerine dayalı bina hasar sınıflandırması niteliği taşımaktadır.

Deprem sonrası bina hasar verileri çoğunlukla düşük hasarlı yapıların baskın olduğu dengesiz bir sınıf dağılımına sahiptir. Bu durum, doğruluk (accuracy) gibi geleneksel performans ölçütlerinin yanıltıcı sonuçlar üretmesine yol açabilmekte; model performanslarının daha dengeli ölçütlerle değerlendirilmesini gerekli kılmaktadır.

Bu bağlamda, çalışmanın temel amacı; 30 Ekim 2020 İzmir Depremi sonrasında Bayraklı ve Bornova ilçelerinde saha gözlemlerine dayalı olarak elde edilen bina hasar verilerini kullanarak, farklı makine öğrenmesi yöntemlerinin hasar sınıflarını ayırt etme performanslarını karşılaştırmak ve en başarılı model yardımıyla bina ölçeğinde mekânsal hasar kestirim haritası üretmektir. En iyi performansı gösteren modelin çıktıları Coğrafi Bilgi Sistemleri (CBS) ortamına aktarılmış ve elde edilen mekânsal desenler mühendislik beklentileri doğrultusunda yorumlanmıştır. Bu yönüyle çalışma, makine öğrenmesi temelli bina hasar kestiriminin karar destek süreçlerinde kullanımına yönelik bütüncül ve uygulanabilir bir çerçeve sunmaktadır.

2. VERİ

2.1) Veri Seti

Bu çalışmada, yapı özellikleri, yerel zemin koşulları ve deprem sonrası hasar bilgilerini birlikte içeren, bina ölçeğinde bütüncül bir mekânsal veri seti oluşturulmuştur. Yapı hasarına ilişkin veriler, 30 Ekim 2020 Sisam Adası (Seferihisar- İzmir) Depremi sonrasında Çevre, Şehircilik ve İklim Değişikliği Bakanlığı tarafından gerçekleştirilen bina bazlı hasar tespit çalışmalarından elde edilmiş ve AFAD Afet Yönetimi Karar Destek Sistemi (AYDES) aracılığıyla temin edilmiştir (AFAD 2022). Bu veriler, saha gözlemlerine dayalı mühendislik değerlendirmelerini içermekte olup, deprem sonrası gerçek hasar durumunu yansıtmaktadır.

Yapı envanterine ilişkin tamamlayıcı bilgiler ise İzmir Büyükşehir Belediyesi Açık Veri Portalı üzerinden Bayraklı ve Bornova ilçeleri için sağlanan yapı verilerinden elde edilmiştir (İzmir Büyükşehir Belediyesi 2024). Bu iki farklı kurumsal kaynaktan temin edilen bina bazlı veri setleri, Coğrafi Bilgi Sistemleri (CBS) ortamında bina kimlik bilgileri esas alınarak eşleştirilmiş, mekânsal olarak koordinatlandırılmış ve tek bir bütüncül envanter yapısı altında birleştirilmiştir. Bu süreçte, farklı format ve içeriklere sahip veri kaynakları ortak bir koordinat referans sistemine dönüştürülmüş ve bina ölçeğinde analizlere olanak sağlayacak şekilde düzenlenmiştir.

Zemin özelliklerine ilişkin veriler büyük ölçüde İzmir Büyükşehir Belediyesi yapı envanteri kapsamında sağlanmış olmakla birlikte, oluşturulan bina veri setinde önemli ölçüde eksik zemin bilgisi bulunduğu tespit edilmiştir. Bu eksikliğin giderilmesi amacıyla, AFAD tarafından desteklenen UDAP-Ç-20-01 kodlu "Topoğrafik ve Jeolojik Sayısal Veriler Kullanılarak Türkiye Ölçeğinde Tahmini Vs30 Haritasının CBS Ortamında Üretilmesi" başlıklı proje (Yılmaz ve diğ. 2023) kapsamında üretilen raster tabanlı tahmini Vs30 verileri kullanılmıştır. Raster-vektör dönüşümleri ve mekânsal

örnekleme yöntemleri aracılığıyla Vs30 değerleri bina ölçeğine indirgenmiş ve veri tabanına entegre edilmiştir. Bu yaklaşım, zemin parametrelerinin mekânsal sürekliliğini koruyarak bina ölçeğinde temsil edilmesini sağlamıştır.

Sonuç olarak, deprem sonrası hasar tespit kayıtları, yapı envanteri bilgileri, zemin parametreleri ve yer hareketine ilişkin bileşenler farklı kurumsal kaynaklardan temin edilerek CBS ortamında bütünleştirilmiş; bina ölçeğinde makine öğrenmesi tabanlı analizlere uygun, kapsamlı ve tutarlı bir mekânsal veri seti oluşturulmuştur.

3. MATERYAL VE YÖNTEM

3.1) Değişkenler ve Tanımlayıcı İstatistikler

Bu çalışmada kullanılan makine öğrenmesi modelleri, bina ölçeğinde yapısal, jeoteknik ve sismolojik özellikleri temsil eden değişkenler kullanılarak eğitilmiştir. Bağımsız değişkenler; yapı geometrisini, yapı tipolojisini, zemin koşullarını ve deprem kaynaklı yer hareketi etkilerini temsil edecek şekilde seçilmiştir. Bağımlı değişken ise, deprem sonrası saha gözlemlerine dayalı olarak belirlenen bina hasar sınıflarını ifade etmektedir.

Aşağıda, analizlerde kullanılan başlıca değişkenler ve bunlara ait tanımlayıcı istatistikler sunulmaktadır.

Kat Sayısı: Binanın taşıyıcı kat adedini temsil etmekte olup, yapı yüksekliği ve buna bağlı olarak deprem etkilerinin büyümesi açısından önemli bir yapısal parametredir. Özellikle çok katlı yapıların yatay yükler altındaki davranışı, düşük katlı yapılara kıyasla daha karmaşık ve kırılabilir olabilmektedir. Tablo 1’de sunulan kat sayısı dağılımı incelendiğinde, çalışma alanındaki yapı stokunun büyük bölümünün 3-5 kat aralığında yoğunlaştığı görülmektedir. Bu durum, Bayraklı ve Bornova ilçelerindeki kentsel yapılaşmanın orta katlı betonarme yapılar ağırlıklı olduğunu göstermektedir.

Tablo 1: Kat Sayısı Dağılımı
Table 1: Distribution of Number of Floors

Kat Aralığı	Bina Sayısı	Oran (%)
1-2 kat	5.321	19.6
3-5 kat	18.930	69.8
6-8 kat	2.183	8.0
9+ kat	704	2.6
Toplam	27.142	100

Yapım Yılı: Yapıların tabii olduğu deprem yönetmeliklerini ve inşaa dönemine özgü mühendislik uygulamalarını dolaylı olarak temsil eden kritik bir parametredir. Türkiye’de deprem yönetmeliklerinde zaman içerisinde önemli güncellemeler yapılmış olup, özellikle 2000 yılı öncesinde inşa edilmiş yapıların daha düşük sismik performans sergilediği bilinmektedir.

Tablo 2’de görüldüğü üzere, çalışma alanındaki yapı stokunun büyük bir bölümü 2000 yılı öncesinde inşa edilmiştir. Bu durum, eski yönetmeliklere göre yapılmış yapıların baskın olduğunu ve deprem hasarı açısından potansiyel riskin yüksek olabileceğini göstermektedir.

Tablo 2: Yapım Yılı Dağılımı
Table 2: Distribution of Construction Year

Yapım Yılı Aralığı	Bina Sayısı	Oran (%)
< 1980	6.598	24.3
1980-2000	14.620	53.9
2001-2010	2.959	10.9
2011-2024	2.954	10.9
Toplam	27.142	100

Taşıyıcı Sistem: Binanın deprem etkileri altındaki davranışını doğrudan belirleyen temel yapısal özelliklerden biridir. Betonarme ve yığma yapılar, malzeme özellikleri, süneklik kapasiteleri ve enerji yutma yetenekleri bakımından önemli farklılıklar göstermektedir.

Tablo 3’te sunulan dağılım, çalışma alanındaki yapı stokunun büyük ölçüde betonarme yapılardan oluştuğunu göstermektedir. Yığma yapıların daha sınırlı bir oranda temsil edilmesi, taşıyıcı sistem değişkeninin veri seti genelinde sınırlı varyans içermesine neden olmaktadır.

Tablo 3: Taşıyıcı Sistem Dağılımı
Table 3: Distribution of Structural System

Taşıyıcı Sistem	Bina Sayısı	Oran (%)
Betonarme	21.666	79.8
Yığma	5.476	20.2
Toplam	27.142	100

Yapı Nizamı: Binaların çevre yapılarla olan geometrik ilişkisini ve olası çarpışma (pounding) etkilerini temsil eden bir parametredir. Özellikle bitişik nizam yapılaşma, deprem sırasında yapılar arası etkileşimi artırabilmektedir.

Tablo 4’te görüldüğü üzere, bitişik ve blok nizam yapıların toplam oranı oldukça yüksektir. Bu durum, çalışma alanındaki yapılaşmanın yoğun ve kompakt bir kentsel dokuya sahip olduğunu göstermektedir.

Tablo 4: Yapı Nizamı Dağılımı
Table 4: Distribution of Building Configuration Types

Yapı Nizamı	Bina Sayısı	Oran (%)
Bitişik Nizam	11.749	43.3
Blok Nizam	10.581	39.0
Ayrık Nizam	4.812	17.7
Toplam	27.142	100

Depreme Uzaklık (Rjb): Bu çalışmada Joyner-Boore uzaklığı (Rjb) kullanılarak temsil edilmiştir. Rjb, bir yapının depremi üreten fayın yüzey izdüşümüne olan en kısa yatay mesafesini ifade etmektedir (Joyner ve Boore 1981). Rjb değerleri, 30 Ekim 2020 İzmir Depremi’ne ait kırılma geometrisi esas alınarak CBS ortamında hesaplanmıştır. Tablo 5’te görüldüğü üzere, çalışma alanındaki binaların büyük bölümü faylara görece uzak bir mesafede konumlanmaktadır. Bu durum, Rjb değişkeninin veri seti genelinde sınırlı bir varyans sergilemesine neden olmuştur.

Tablo 5: Depreme Uzaklık Dağılımı
Table 5: Distribution of Distance to Earthquake

Rjb Aralığı (km)	Bina Sayısı	Oran (%)
< 50	0	0.0
50-60	0	0.0
60-70	26.988	99.43
>70	154	0.57
Toplam	27.142	100

Zemin Büyütme Katsayısı: Yerel zemin koşullarının yer hareketini büyütme potansiyelini temsil etmektedir. Bu parametre, Vs30 değerlerinden türetilmiş olup, yerel zemin etkilerinin bina hasarı üzerindeki rolünü dolaylı olarak yansıtmaktadır. Tablo 6'da sunulan dağılım, çalışma alanında zemin büyütme katsayısının geniş bir aralıkta değiştiğini ve özellikle orta-yüksek büyütme değerlerine sahip alanların yaygın olduğunu göstermektedir.

Tablo 6: Zemin Büyütme Katsayısı Dağılımı
Table 6: Distribution of Site Amplification Factor

Zemin Büyütme Aralığı	Bina Sayısı	Oran (%)
≤ 1.1	1.309	4.8
1.1 - 1.3	9.437	34.8
1.3 - 1.5	3.168	11.7
1.5 - 1.8	10.453	38.5
> 1.8	2.775	10.2
Toplam	27.142	100

Bağımlı Değişken: Bu çalışmada bağımlı değişken, deprem sonrası saha gözlemlerine dayalı olarak belirlenen bina hasar sınıflarını temsil etmektedir. Hasar sınıfları, mühendislik değerlendirmeleri esas alınarak üç kategori altında tanımlanmıştır:

Düşük hasar: Hasarsız ve az hasarlı yapılar
Orta hasar: Orta hasarlı yapılar
Yüksek hasar: Ağır hasarlı ve yıkık yapılar

Hasar sınıflarının dağılımı, veri setinde belirgin bir dengesizlik olduğunu göstermektedir. Bu durum, izleyen bölümde açıklanan veri ön işleme ve modelleme stratejilerinin belirlenmesinde temel bir rol oynamıştır.

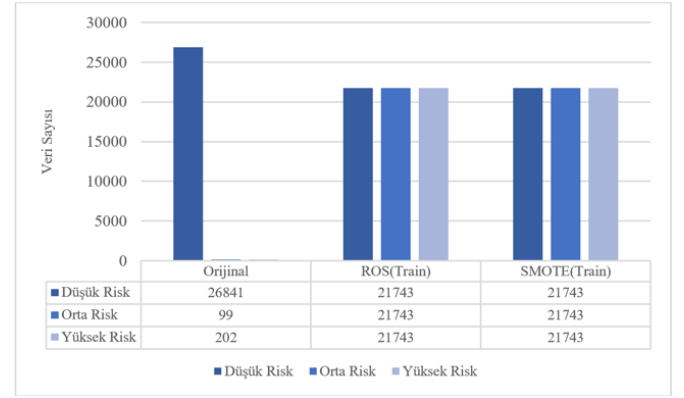
Veri setinin bu yapısı dikkate alınarak, izleyen bölümde veri ön işleme adımları, sınıf dengesizliği ile başa çıkmak için kullanılan yöntemler ve makine öğrenmesi modellerinin kurulumu ayrıntılı olarak açıklanmaktadır.

3.2) Veri Dengesizliği ve Ön İşleme

Bu çalışmada kullanılan bina hasar veri seti, deprem sonrası saha gözlemlerine dayalı olarak oluşturulmuş olup, düşük hasar sınıfının belirgin biçimde baskın olduğu aşırı dengesiz bir sınıf dağılımı sergilemektedir. Özellikle hasarsız ve az hasarlı yapıların sayısal üstünlüğü, orta ve yüksek hasar sınıflarının ise görece sınırlı sayıda temsil edilmesi, makine öğrenmesi modellerinin çoğunluk sınıfına aşırı uyum göstermesine neden olabilmektedir. Literatürde yaygın olarak vurgulandığı üzere, bu tür dengesiz veri yapıları, doğruluk (Accuracy) temelli

performans ölçütlerinin yanıltıcı sonuçlar üretmesine yol açmakta ve azınlık sınıfların ayırt edilmesini güçleştirmektedir (He ve Garcia 2009). Bu nedenle, modelleme sürecinde yalnızca genel doğruluk değerlerine odaklanmak yerine, sınıflar arası dengeyi dikkate alan değerlendirme ölçütlerinin kullanılması benimsenmiştir. Çalışmada model performansları Balanced Accuracy, Macro-F1 ve Cohen's Kappa gibi dengesiz veri setlerine duyarlı metrikler aracılığıyla değerlendirilmiştir. Bu yaklaşım, özellikle orta ve yüksek hasar sınıflarının doğru biçimde temsil edilmesini ve model genelleme yeteneğinin daha gerçekçi biçimde ölçülmesini amaçlamaktadır.

Sınıf dengesizliğinin model performansı üzerindeki olumsuz etkilerini azaltmak amacıyla, yalnızca eğitim veri setine uygulanmak üzere iki farklı örnekleme yöntemi kullanılmıştır: Random Over Sampling (ROS) ve Synthetic Minority Over-sampling Technique (SMOTE). Test veri seti ise model performanslarının tarafsız biçimde değerlendirilebilmesi amacıyla Şekil 1'de görüldüğü gibi orijinal sınıf dağılımı korunarak bırakılmıştır.



Şekil 1: Hasar sınıflarının frekans dağılımı (orijinal ve dengelenmiş veri)

Figure 1: Frequency distribution of damage classes (original and balanced data)

Random Over Sampling (ROS) yöntemi, azınlık sınıflara ait örneklerin rastgele çoğaltılması esasına dayanmaktadır. Bu yöntem, sınıflar arası sayısal dengeyi hızlı biçimde sağlamakla birlikte, aynı örneklerin tekrar edilmesi nedeniyle bazı modellerde aşırı öğrenme (overfitting) riskini artırabilmektedir. Buna karşın, düşük hesaplama maliyeti ve uygulanabilirliği nedeniyle literatürde sıklıkla tercih edilen bir yaklaşım olarak öne çıkmaktadır.

Synthetic Minority Over-sampling Technique (SMOTE) yöntemi ise azınlık sınıflara ait örnekler arasında öznitelik uzayında enterpolasyon yaparak sentetik veri noktaları üretmektedir. Bu yaklaşım, yalnızca mevcut örneklerin tekrar edilmesi yerine, sınıf içi varyasyonu artırarak daha gerçekçi bir veri dağılımı oluşturmayı hedeflemektedir (Chawla ve diğ. 2002). Böylece modelin genelleme kabiliyeti artmakta ve sınıflar arası karar sınırlarının daha dengeli biçimde öğrenilmesi sağlanmaktadır.

Örnekleme işlemleri sonrasında, tüm kategorik değişkenler sayısallaştırılmış, sürekli değişkenler normalize edilerek modeller için karşılaştırılabilir bir özellik uzayı

oluşturulmuştur. Bu ön işleme adımları, farklı makine öğrenmesi algoritmalarının aynı veri temeli üzerinde tutarlı biçimde eğitilmesini ve performanslarının adil şekilde karşılaştırılmasını sağlamıştır.

Sonuç olarak, bu çalışmada sınıf dengesizliği problemi yalnızca teknik bir veri ön işleme adımı olarak değil, model seçimi ve değerlendirme sürecini doğrudan etkileyen temel bir metodolojik unsur olarak ele alınmıştır. Kullanılan örnekleme stratejileri ve performans ölçütleri, deprem sonrası bina hasar tahmini gibi karar destek odaklı uygulamalarda model çıktılarının daha güvenilir ve yorumlanabilir olmasına katkı sağlamaktadır.

3.3) Modelleme Stratejisi ve Kullanılan Algoritmalar

Bu çalışmada, deprem sonrası bina hasar sınıflarının tahmin edilmesi amacıyla farklı makine öğrenmesi algoritmaları karşılaştırmalı bir modelleme stratejisi kapsamında değerlendirilmiştir. Modelleme süreci, veri setinin yapısal özellikleri, sınıf dengesizliği durumu ve çalışmanın karar destek odaklı amacı dikkate alınarak tasarlanmıştır. Tüm modeller, aynı öznitelik seti ve aynı eğitim-test bölünmesi kullanılarak eğitilmiş; böylece elde edilen performans sonuçlarının doğrudan karşılaştırılabilir olması sağlanmıştır.

Bağımlı değişken olarak, saha gözlemlerine dayalı üç sınıflı bina hasar durumu (düşük, orta, yüksek) kullanılmıştır. Bağımsız değişkenler ise yapısal (kat sayısı, yapım yılı, taşıyıcı sistem, yapı nizamı), jeoteknik (Vs30'dan türetilen zemin büyütme katsayısı) ve deprem etkisini temsil eden parametrelerden (PGA ve Rjb) oluşmaktadır. Bu değişken seti, literatürde bina hasar tahmininde yaygın olarak kullanılan ve mühendislik açıdan anlamlı öznitelikleri kapsamaktadır.

Modelleme sürecinde, farklı algoritmaların dengesiz veri yapısı altındaki davranışlarını incelemek amacıyla hem tekil öğreniciler hem de topluluk (ensemble) ve artırılmalı (boosting) yöntemler değerlendirilmiştir. Bu kapsamda Decision Tree (DT), Random Forest (RF), Extreme Gradient Boosting (XGBoost), Yapay Sinir Ağları (ANN) ve Destek Vektör Makineleri (SVM) algoritmaları kullanılmıştır. Seçilen algoritmalar, farklı öğrenme mekanizmalarına sahip olmaları nedeniyle hasar sınıflarını ayırt etme kapasitelerinin karşılaştırılmasına olanak sağlamaktadır.

Decision Tree algoritması, karar kurallarının açık biçimde izlenebilmesi ve yorumlanabilirliği nedeniyle temel bir referans model olarak değerlendirilmiştir (Quinlan 1993). Ancak tek ağaç yapısının, karmaşık ve gürültülü veri setlerinde genelleme kabiliyeti sınırlı olabildiği bilinmektedir. Bu nedenle Decision Tree modeli, daha gelişmiş yöntemlerle karşılaştırmalı bir çerçevede ele alınmıştır.

Random Forest algoritması, çok sayıda karar ağacının rastgele alt örneklem ve öznitelik alt kümeleri üzerinden eğitilmesi esasına dayanmakta olup, aşırı öğrenme riskini azaltarak daha kararlı tahminler üretebilmektedir (Breiman 2001). Bu özelliği sayesinde Random Forest, dengesiz veri setlerinde azınlık sınıflarını belirli ölçüde ayırt edebilen güçlü bir topluluk öğrenme yöntemi olarak öne çıkmaktadır.

Extreme Gradient Boosting (XGBoost) algoritması ise, yanlış sınıflandırılan örneklere iteratif olarak daha fazla ağırlık

vererek model performansını artıran artırılmalı bir öğrenme yaklaşımı sunmaktadır (Chen ve Guestrin 2016). Bu yönüyle XGBoost, özellikle azınlık sınıflarının temsilinin sınırlı olduğu veri setlerinde dengeli sınıflandırma başarımı elde etme potansiyeline sahiptir. Çalışmada XGBoost modeli, hem örnekleme uygulanmamış (baseline) hem de dengelenmiş veri setleri üzerinde değerlendirilmiştir.

Yapay Sinir Ağları (ANN), doğrusal olmayan karmaşık ilişkileri modelleyebilme yeteneği nedeniyle bina hasar tahmini çalışmalarında sıklıkla kullanılan yöntemler arasındadır (Rumelhart ve diğ. 1986, Zhu ve diğ. 2020). Ancak ANN modellerinin performansı, eğitim verisinin büyüklüğüne ve sınıf dağılımına duyarlı olduğundan, bu çalışmada dengesiz veri yapısı altındaki davranışları özellikle incelenmiştir.

Destek Vektör Makineleri (SVM) ise sınıflar arasındaki karar sınırlarını maksimum marjin prensibiyle belirleyen güçlü bir sınıflandırma algoritmasıdır (Cortes ve Vapnik 1995). Bununla birlikte, büyük ölçekli ve aşırı örneklenmiş veri setlerinde hesaplama maliyetinin artması ve ölçeklenebilirlik sorunları literatürde sıklıkla rapor edilmektedir. Bu nedenle SVM modelleri, yalnızca hesaplanabilirliği sağlanan senaryolar üzerinden değerlendirilmiş ve sonuçlar bu bağlamda yorumlanmıştır.

Tüm modeller için hiperparametre optimizasyonu GridSearchCV yöntemi kullanılarak gerçekleştirilmiş ve beş katlı çapraz doğrulama uygulanmıştır. Model performansları, Balanced Accuracy, Macro-F1 ve Cohen's Kappa ölçütleri üzerinden değerlendirilerek hem baskın sınıfın etkisi hem de azınlık sınıflarının ayırt edilme başarımı birlikte dikkate alınmıştır.

Bu bütüncül modelleme stratejisi sayesinde, farklı makine öğrenmesi algoritmalarının deprem sonrası bina hasar tahminindeki güçlü ve zayıf yönleri sistematik olarak karşılaştırılmış; elde edilen bulgular bir sonraki bölümde ayrıntılı olarak sunulmuştur.

3.4) Eğitim-Test Ayrımı ve Çoğaltılabilirlik

Bu çalışmada kullanılan bina ölçekli veri seti, model performansının tarafsız ve genellebilir biçimde değerlendirilebilmesi amacıyla eğitim ve test üzere iki alt kümeye ayrılmıştır. Veri seti, sınıf dağılımının korunmasını sağlamak için katmanlı örnekleme (stratified sampling) yaklaşımı kullanılarak %70 eğitim ve %30 test oranında bölünmüştür. Böylece, özellikle azınlık sınıflarının hem eğitim hem de test aşamalarında temsil edilmesi güvence altına alınmıştır.

Çalışmada yer alan tüm rassal işlemlerde, sonuçların yeniden üretilebilirliğini sağlamak amacıyla sabit bir rassal tohum değeri (random_state = 42) kullanılmıştır. Model eğitim süreci yalnızca eğitim veri seti üzerinde gerçekleştirilmiş, performans değerlendirmeleri ise tamamen bağımsız test veri seti üzerinden raporlanmıştır. Bu yaklaşım, veri sızıntısının (data leakage) önüne geçerek, modellerin gerçek tahmin yeteneklerinin daha sağlıklı biçimde ölçülmesini amaçlamaktadır.

3.5) Hiperparametre Optimizasyonu: GridSearchCV ve 5-Katlı Çapraz Doğrulama

Makine öğrenmesi modellerinin performansı, hiperparametre seçimlerine yüksek derecede duyarlıdır. Bu nedenle çalışmada kullanılan tüm algoritmalar için hiperparametre optimizasyonu, GridSearchCV yöntemi kullanılarak gerçekleştirilmiştir. Optimizasyon sürecinde, sınıf dağılımının korunmasını sağlamak amacıyla 5-katlı Stratified Cross-Validation yaklaşımı benimsenmiştir. Bu yöntem, özellikle dengesiz veri setlerinde modelin genellenebilirliğini artırmak açısından literatürde önerilen bir yaklaşımdır (He ve Garcia 2009, Fernández ve diğ. 2018).

Ağaç tabanlı modellerde (DT, RF, XGBoost) kullanılan $n_{estimators}$ ve max_depth parametreleri, modelin temsil gücü ile aşırı öğrenme arasındaki dengeyi kontrol etmektedir. Literatürde, çok düşük ağaç sayılarının yetersiz öğrenmeye, aşırı yüksek değerlerin ise hesaplama maliyetinde artışa yol açtığı belirtilmektedir (Breiman, 2001; Chen ve Guestrin, 2016). Bu doğrultuda Random Forest için 200-400, XGBoost için 300-600 ağaç aralığı; max_depth için ise DT ve RF modellerinde 5-30, XGBoost'ta 3-7 aralıkları taranmıştır.

XGBoost algoritmasında kullanılan $learning_rate$ parametresi, her bir ağacın nihai modele katkı oranını belirlemekte olup, küçük öğrenme oranlarının daha kararlı ve genellenebilir modeller ürettiği bilinmektedir (Chen ve Guestrin 2016). Bu çalışmada 0.03-0.10 aralığı değerlendirilmiştir. Ayrıca $subsample$ ve $colsample_bytree$ parametreleri (0.8-0.9) ile modelin rastgelelik düzeyi artırılarak aşırı öğrenmenin sınırlandırılması hedeflenmiştir.

SVM modellerinde C ve gamma parametreleri, sırasıyla yanlış sınıflandırmaya verilen ceza ile karar sınırının esnekliğini kontrol etmektedir (Cortes ve Vapnik 1995). ANN modellerinde ise $hidden_layer_sizes$ ve alpha parametreleri, ağ mimarisi ile düzenleme düzeyi arasındaki dengeyi sağlamaya yönelik olarak belirlenmiştir (Rumelhart ve diğ. 1986, Zhu ve diğ. 2020).

Tüm modeller için en uygun hiperparametre kombinasyonları, Balanced Accuracy metriğine göre seçilmiş; Macro F1 ve Cohen's Kappa değerleri ikincil performans ölçütleri olarak raporlanmıştır. Hiperparametre aralıkları, literatürde önerilen değerler ve çalışmanın erken aşamalarında gerçekleştirilen ön deneme analizleri birlikte dikkate alınarak belirlenmiştir.

3.6) Accuracy Paradox ve Değerlendirme Metriklerinin Seçimi

Dengesiz sınıf dağılımına sahip veri setlerinde, yalnızca genel doğruluk (accuracy) değerine odaklanılması yanıltıcı sonuçlara yol açabilmektedir. Bu durum, literatürde accuracy paradox olarak tanımlanmaktadır (He ve Garcia 2009, Sun ve diğ. 2009). Bu çalışmada da bazı modellerin yüksek accuracy değerleri üretmesine rağmen, orta ve yüksek hasar sınıflarını ayırt etmede yetersiz kaldığı gözlemlenmiştir.

Bu nedenle model performansları, sınıf-duyarlı ölçütler olan Balanced Accuracy, Macro Ortalama F1-Skoru ve Cohen's Kappa katsayısı birlikte kullanılarak değerlendirilmiştir. Balanced Accuracy, her sınıfın duyarlılığını eşit ağırlıkla dikkate alırken; Macro F1-skoru, azınlık sınıflarının Precision ve Recall değerlerini baskın sınıfın etkisinden bağımsız olarak yansıtmaktadır. Cohen's Kappa ise model başarısını rastlantısal uyumdan arındırarak ölçmektedir.

Bu çoklu metrik yaklaşımı sayesinde, modeller yalnızca baskın sınıf üzerindeki başarımına göre değil, tüm hasar sınıflarını ayırt edebilme yeteneklerine göre karşılaştırılmıştır.

3.7) Çoklu Bağlantı ve Eşik Ayarlama Yaklaşımı

Bu çalışmada kullanılan makine öğrenmesi algoritmaları, doğrusal varsayımlara dayanmayan ve değişkenler arası yüksek korelasyona karşı görece dayanıklı yöntemlerdir. Özellikle ağaç tabanlı modellerde (Decision Tree, Random Forest ve XGBoost), bölünme mekanizmaları değişkenlerin marjinal katkısına dayandığından, çoklu bağlantı (multicollinearity) problemi klasik regresyon tabanlı yaklaşımlarda olduğu kadar kritik bir sınırlılık oluşturmamaktadır (Breiman 2001). Bu nedenle, VIF benzeri istatistiksel çoklu bağlantı analizleri çalışmada öncelikli bir adım olarak ele alınmamış; değişkenlerin etkileri model performansı ve değişken önem analizleri üzerinden değerlendirilmiştir.

Öte yandan, sınıflandırma eşik değerlerinin (threshold tuning) optimize edilmesinin, özellikle azınlık sınıflarına ait geri çağırma (recall) performansını artırabileceği bilinmektedir. Bu kapsamda, çalışmada en iyi performansı gösteren XGBoost modeli için olasılık tabanlı eşik ayarlama yaklaşımı deneysel olarak değerlendirilmiştir. Yüksek hasar sınıfı için farklı eşik değerleri test edilmiş; elde edilen sonuçlar, varsayılan argmax karar kuralı ile karşılaştırılmıştır. Analizler, belirli eşik değerlerinde Balanced Accuracy ölçütünde sınırlı artışlar sağlanabildiğini; ancak bu artışların Macro F1-skorunda düşüş ve Cohen's Kappa katsayısında yalnızca marjinal iyileşmeler ile birlikte gerçekleştiğini göstermiştir. Bu bulgular, eşik ayarlamasının metrik bağımlı kazanımlar sunduğunu ve genel sınıf dengesi açısından tutarlı bir iyileşme sağlamadığını ortaya koymaktadır.

Tablo 7: XGBoost modeli için varsayılan karar kuralı ve eşik ayarlama sonuçlarının karşılaştırılması
Table 7: Comparison of default decision rule and threshold tuning results for the XGBoost model

Yaklaşım	Balanced Accuracy	Macro F1	Cohen's Kappa	Eşik Değeri
Varsayılan (argmax)	0.661	0.700	0.696	-
Threshold tuning ($t = 0.20$)	0.677	0.682	0.703	0.20

Tablo 7 incelendiğinde, eşik ayarlama yaklaşımı ile Balanced Accuracy değerinde sınırlı bir artış sağlandığı görülmektedir. Ancak bu artış, Macro F1-skorunda düşüğe ve Cohen's Kappa katsayısında yalnızca marjinal bir iyileşmeye eşlik etmektedir. Bu durum, eşik ayarlamasının belirli metrikler açısından avantaj sağlasa da, tüm sınıflar için dengeli ve tutarlı bir performans artışı sunmadığını göstermektedir. Bu nedenle çalışmada, modeller arası karşılaştırılabilirliği korumak amacıyla varsayılan argmax karar kuralı esas alınmıştır

Bu nedenle çalışmada, modeller arası karşılaştırılabilirliği ve karar tutarlılığını korumak amacıyla varsayılan argmax karar kuralı esas alınmıştır. Eşik ayarlama yaklaşımlarının, belirli risk senaryolarına veya uygulama odaklı karar destek sistemlerine yönelik ileri çalışmalarda daha ayrıntılı biçimde ele alınması planlanmaktadır.

Bu bölümde tanımlanan veri seti, ön işleme adımları, modelleme stratejisi ve performans değerlendirme ölçütleri doğrultusunda, farklı makine öğrenmesi algoritmalarının bina hasar sınıflarını ayırt etme yetenekleri karşılaştırmalı olarak analiz edilmiştir. İzleyen bölümde, modellerin Balanced Accuracy, Macro F1 ve Cohen's Kappa gibi sınıf-duyarlı ölçütler üzerinden elde edilen performans sonuçları sunulmakta; sınıf bazlı davranışlar, örnekleme yöntemlerinin etkileri ve en iyi performansı gösteren modelin mekânsal çıktıları ayrıntılı biçimde değerlendirilmektedir.

4. BULGULAR

Bu çalışmada, 30 Ekim 2020 Sisam Adası (Seferihisar-İzmir) Depremi sonrasında Bayraklı ve Bornova ilçelerinde gözlenen bina hasar sınıflarının tahmini amacıyla uygulanan makine öğrenmesi modellerinin performansları, dengesiz veri yapısı dikkate alınarak sınıf-duyarlı ölçütler üzerinden değerlendirilmiştir. Elde edilen mekânsal hasar örüntüleri, Türkiye'de farklı bölgeler için gerçekleştirilen ve makine öğrenmesi ile CBS entegrasyonunu kullanan benzer çalışmalarla uyumlu sonuçlar sunmaktadır (Yılmaz ve Yıldırım 2022). Bulgular; genel performans ölçütleri, sınıf bazlı karşılaştırmalar, örnekleme yöntemlerinin etkisi, en iyi modelin belirlenmesi ve mekânsal çıktılar olmak üzere alt başlıklar altında sunulmaktadır.

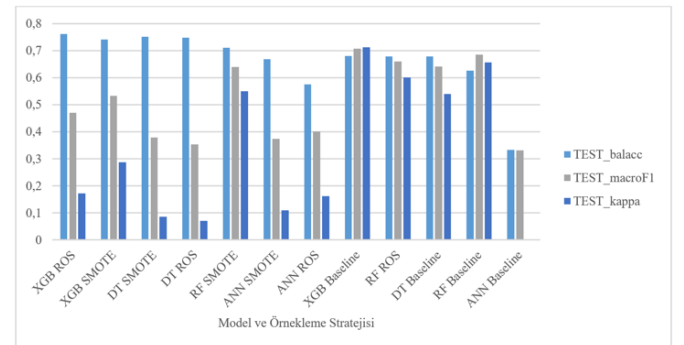
4.1) Genel Değerlendirme Ölçütleri

Modellerin genel performansları Balanced Accuracy, Macro F1-skoru ve Cohen's Kappa katsayısı kullanılarak değerlendirilmiştir. Elde edilen sonuçlar Tablo 8'de görüldüğü gibi, yalnızca yüksek doğruluk değerlerinin model başarısını temsil etmek için yeterli olmadığını açık biçimde ortaya koymuştur. Özellikle düşük hasar sınıfının baskın olduğu veri setinde, bazı modeller yüksek accuracy üretmesine rağmen orta ve yüksek hasar sınıflarını ayırt etmede yetersiz kalmıştır.

Tablo 8: Modellerin karşılaştırılması
Table 8: Comparison of models

Model	Sampling	CV BAcc	CV MF1	CV κ	Test BAcc	Test MF1	Test κ
DT	Baseline	0.586	0.582	0.486	0.678	0.641	0.540
DT	ROS	0.687	0.363	0.066	0.747	0.354	0.071
DT	SMOTE	0.700	0.393	0.086	0.752	0.378	0.086
RF	Baseline	0.564	0.627	0.598	0.626	0.686	0.656
RF	ROS	0.601	0.639	0.586	0.678	0.660	0.600
RF	SMOTE	0.646	0.627	0.510	0.710	0.639	0.549
ANN	Baseline	0.336	0.336	0.009	0.333	0.332	0.000
ANN	ROS	0.632	0.382	0.113	0.575	0.400	0.162
ANN	SMOTE	0.641	0.374	0.089	0.668	0.375	0.110
SVM	Baseline	0.658	0.488	0.229	0.386	0.411	0.182
SVM	ROS	0.636	0.510	0.280	0.666	0.532	0.323
XGB	Baseline	0.613	0.657	0.657	0.680	0.708	0.713
XGB	ROS	0.790	0.479	0.180	0.761	0.470	0.173
XGB	SMOTE	0.740	0.551	0.319	0.741	0.533	0.288

Genel değerlendirme ölçütleri Şekil 2'de yer alan karşılaştırma ile değerlendirildiğinde, XGBoost (Baseline) ve Random Forest modellerinin dengeli ve tutarlı performanslar sergilediği görülmüştür. Bu modeller, hem baskın sınıfı doğru tahmin edebilmiş hem de azınlık sınıflarında kabul edilebilir düzeyde ayırt edicilik sağlamıştır. Buna karşılık, Decision Tree ve ANN tabanlı modellerde performans ölçütleri arasında belirgin dalgalanmalar gözlemlenmiş; bu durum söz konusu modellerin dengesiz veri yapısı altında kararlı sonuçlar üretmekte zorlandığını göstermiştir.



Şekil 2: Modellerin karşılaştırılması
Figure 2: Comparison of models

SVM modelinde, baseline durumda oldukça düşük bir Balanced Accuracy değeri gözlenirken, SVM-ROS uygulanmasıyla performansta belirgin bir artış sağlanmıştır. SVM modelinde SMOTE uygulanması durumunda hesaplama maliyetinin önemli ölçüde arttığı ve analiz sürecinin tamamlanamadığı görülmüştür. Bu bulgu, SVM'nin aşırı dengesiz ve çok sınıflı bina hasar verilerinde örnekleme yöntemlerine yüksek derecede duyarlı olduğunu göstermektedir.

4.2) Accuracy Paradox'un Bu Çalışmadaki Etkisi

Veri setinde düşük hasar sınıfının baskın olması, accuracy paradox olarak bilinen yanıltıcı performans algısına yol açmıştır. Bazı model konfigürasyonlarında accuracy değerleri %99'a yaklaşmasına rağmen, Cohen's Kappa ve Macro F1-skorlarının düşük kalması, model başarısının rastlantısal uyumdan yeterince ayrışmadığını göstermektedir.

Bu bulgu, dengesiz hasar verileri üzerinde yalnızca accuracy temelli bir değerlendirme yapılmasının riskli olduğunu ve azınlık sınıflarını göz ardı edebileceğini açıkça ortaya koymaktadır. Balanced Accuracy, Macro F1 ve Cohen's Kappa metriklerinin birlikte kullanılması sayesinde, modellerin tüm hasar sınıflarını ayırt etme kapasitesi daha gerçekçi biçimde değerlendirilebilmiştir.

4.3) Modellerin Sınıf Bazlı Karşılaştırılması

Sınıf bazlı değerlendirme sonuçları, modeller arasında özellikle orta ve yüksek hasar sınıflarının tahmininde belirgin farklılıklar bulunduğunu göstermiştir. Düşük hasar sınıfı tüm modeller tarafından yüksek doğrulukla tahmin edilirken, orta ve yüksek hasar sınıflarında model performansları belirgin biçimde ayrılmıştır.

XGBoost modeli, orta ve yüksek hasar sınıflarında daha dengeli duyarlılık ve F1-skorları üreterek öne çıkmıştır. Bu durum, boosting tabanlı yaklaşımın, yanlış sınıflandırılan örneklerle iteratif olarak daha fazla ağırlık vermesi sayesinde azınlık sınıflarını daha etkin temsil edebilmesiyle açıklanmaktadır. Random Forest modelleri de sınıf bazlı karşılaştırmalarda kararlı sonuçlar sunmuş; özellikle Cohen's Kappa değerleri,

sınıflar arası ayrımın rastlantısal uyumun ötesinde gerçekleştirildiğini göstermiştir.

Buna karşılık, Decision Tree modellerinde örnekleme yöntemleri uygulanmasına rağmen orta ve yüksek hasar sınıflarında elde edilen kazanımlar sınırlı kalmıştır. ANN ve SVM modellerinde ise veri artırma yöntemleri ile belirli iyileşmeler gözlemlense de, sınıf bazlı performans kararlılığı istenen düzeye ulaşmamıştır. Özellikle SVM modelinde SMOTE uygulanması durumunda hesaplama maliyetinin önemli ölçüde arttığı ve analiz sürecinin tamamlanamadığı görülmüştür.

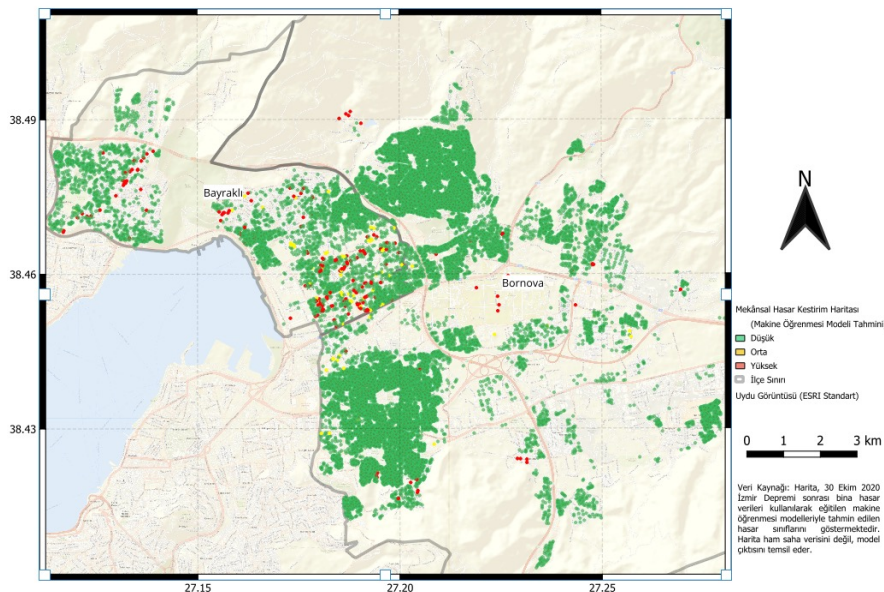
4.4) Örnekleme Yöntemlerinin (ROS-SMOTE) Model Performansına Etkisi

Random Over Sampling (ROS) ve SMOTE yöntemlerinin etkileri incelendiğinde, bu yaklaşımların tüm modeller için otomatik bir performans artışı sağlamadığı görülmüştür. Bazı model konfigürasyonlarında Balanced Accuracy değerleri artarken, Macro F1 ve Cohen's Kappa değerlerinde sınırlı iyileşmeler ya da düşüşler gözlemlenmiştir.

Özellikle ROS uygulamalarında, azınlık sınıfına ait örneklerin yinelenmesi nedeniyle bazı modellerde aşırı öğrenme eğilimi ortaya çıkmıştır. SMOTE uygulamalarında ise sınıf dağılımı daha dengeli hale gelmiş olsa da, sentetik örneklerin karar uzayında gerçekçi olmayan yoğunluklar oluşturduğu ve bunun test performansında dalgalanmalara yol açtığı gözlemlenmiştir. Ensemble tabanlı modellerin, örnekleme yöntemlerine karşı daha dirençli olduğu ve Baseline senaryolarda dahi tatmin edici performanslar sergilediği belirlenmiştir.

4.5) En İyi Modelin Belirlenmesi ve CBS Tabanlı Mekânsal Bulgular

Genel ve sınıf bazlı performans ölçütleri birlikte değerlendirildiğinde, XGBoost (Baseline) modelinin bu çalışma kapsamında en dengeli ve güvenilir sonuçları ürettiği belirlenmiştir. Bu model hem istatistiksel performans ölçütleri hem de sınıf bazlı ayrım gücü açısından diğer modellerin önüne geçmiştir.

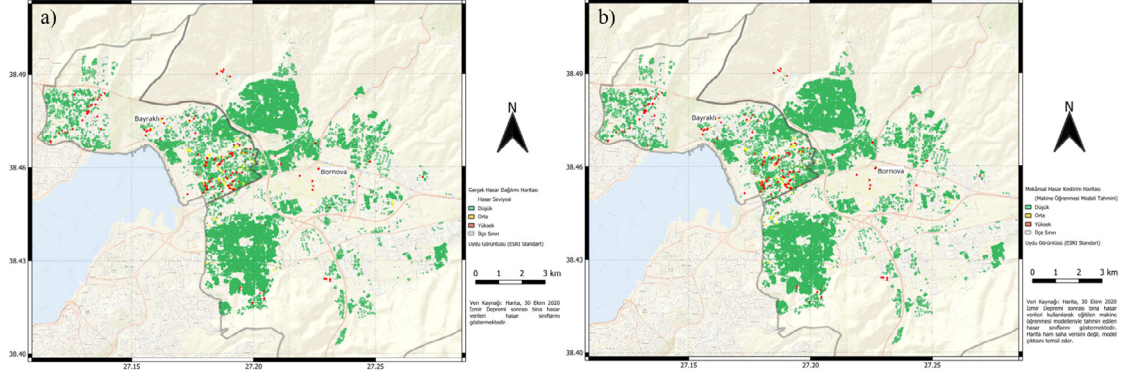


Şekil 3: Mekânsal Hasar Kestirim Haritası
 Figure 3: Spatial Damage Estimation Map

Seçilen modelin bina ölçeğindeki tahmin sonuçları CBS ortamına aktarılmış ve mekânsal hasar kestirim haritası üretilmiştir. Şekil 3'te elde edilen harita incelendiğinde, yüksek hasar sınıfının; zayıf zemin koşullarına sahip, zemin büyütme değerlerinin yüksek olduğu ve eski yapı stokunun yoğunlaştığı bölgelerde belirgin biçimde kümelendiği görülmektedir. Düşük hasar sınıfının ise daha çok yeni yapıların ve görece sağlam zemin koşullarının bulunduğu alanlarda yoğunlaştığı belirlenmiştir. Bu mekânsal desen, model çıktılarının mühendislik beklentileriyle tutarlı olduğunu göstermektedir.

4.6) Mekânsal Hasar Kestirimi ve Gerçek Hasar Dağılımı ile Karşılaştırma

Şekil 4'te, en iyi performansı gösteren XGBoost (Baseline) modeli kullanılarak üretilen bina ölçekli hasar kestirim haritası ile 30 Ekim 2020 İzmir Depremi sonrasında saha gözlemlerine dayalı olarak elde edilen gerçek hasar dağılımı yan yana sunulmaktadır. İki harita birlikte değerlendirildiğinde, yüksek hasar sınıfına ait yapıların özellikle Bayraklı ilçesinde ve alüvyal zeminlerin yaygın olduğu bölgelerde mekânsal olarak benzer kümelenmeler gösterdiği dikkat çekmektedir. Bu durum, modelin hasar dağılımının genel mekânsal örüntüsünü yakalayabildiğini göstermektedir.



Şekil 4: Gerçek Hasar Dağılımı ve Mekânsal Hasar Kestirimi Haritaları a) 30 Ekim 2020 İzmir Depremi sonrası saha gözlemlerine dayalı gerçek hasar dağılımı b) XGBoost (Baseline) modeli ile üretilen bina ölçekli hasar kestirim haritası
Figure 4: Observed Damage Distribution and Spatial Damage Estimation Maps: (a) observed damage distribution based on post-earthquake field surveys following the 30 October 2020 İzmir earthquake; (b) building-level damage estimation map produced using the XGBoost (Baseline) model

Model tahmin haritası, özellikle yüksek hasar sınıfının Bayraklı kıyı kesimi ve zayıf zemin koşullarının yoğunlaştığı bölgelerde

kümelendiğini göstermekte olup, bu mekânsal dağılım gerçek hasar gözlemleriyle yüksek düzeyde örtüşmektedir.

Tablo 9: Bina bazlı gerçek hasar sınıfları ile model tahminlerinin karşılaştırılması
Table 9: Comparison of building-level observed damage classes and model estimation

Gerçek Hasar Sınıfı	Tahmin: Düşük	Tahmin: Orta	Tahmin: Yüksek	Toplam
Düşük (0)	26 841	0	0	26 841
Orta (1)	21	77	1	99
Yüksek (2)	5	0	197	202
Toplam	26 867	77	198	27 142

Tablo 9'da bina bazlı gerçek hasar sınıfları ile XGBoost (Baseline) modeli tarafından üretilen tahmin sonuçları karşılaştırmalı olarak sunulmaktadır. Baskın düşük hasar sınıfı tümüyle doğru sınıflandırılmış olup, bu durum genel doğruluk oranını yükseltmektedir. Bununla birlikte, karar destek açısından kritik öneme sahip yüksek hasar sınıfında 202 binanın 197'sinin doğru biçimde tahmin edilmesi, modelin riskli yapıların belirlenmesinde yüksek ayırt edicilik sergilediğini göstermektedir.

Orta hasar sınıfında gözlenen sınırlı karışma, saha hasar tespitlerinde bu sınıfın doğası gereği taşıdığı belirsizliklerle uyumludur. Genel olarak tablo, model tahminlerinin gerçek hasar desenleriyle yüksek düzeyde örtüştüğünü ve sonuçların mühendislik beklentileriyle tutarlı olduğunu ortaya koymaktadır. Bununla birlikte, bazı yerel farklılıkların ve ölçek

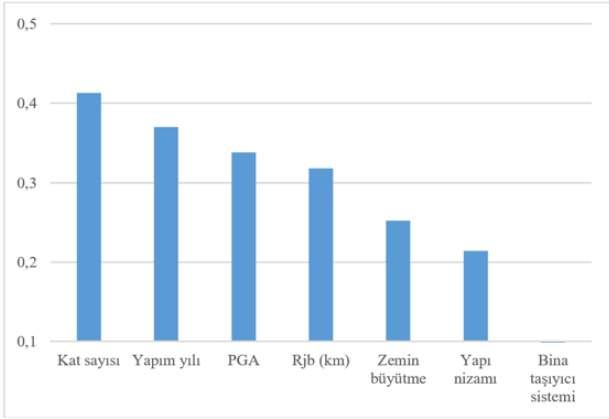
etkilerinin gözlemlendiği alanlar da bulunmaktadır. Bu farklılıklar; bina bazlı hasar tespitlerindeki gözlemsel belirsizlikler, modele dâhil edilmeyen yerel yapı özellikleri ve zemin heterojenliği gibi faktörlerle ilişkilendirilebilir. Dolayısıyla bu karşılaştırma, modelin birebir bina bazlı doğruluğunu değil, mekânsal eğilimleri ve görece risk dağılımını temsil etmektedir.

Elde edilen bu sonuçlar, makine öğrenmesi tabanlı hasar kestirim modellerinin, deprem sonrası hızlı durum değerlendirmesi ve önceliklendirme çalışmalarında destekleyici bir araç olarak kullanılabileceğini göstermektedir.

4.7) En İyi Model İçin Değişken Önem Analizi

En iyi performansı sağlayan XGBoost (baseline) modeli için değişken önem analizi, permutation importance yöntemi kullanılarak gerçekleştirilmiştir. Bu yaklaşımda, her bir

değişkenin değerleri rastgele permüte edilerek modelin Balanced Accuracy ölçütünde meydana gelen ortalama performans düşüşü hesaplanmıştır. Elde edilen sonuçlar Şekil 5'te sunulmaktadır.



Şekil 5: Değişken önem karşılaştırılması
Figure 5: Comparison of feature importance

Analiz sonuçları, kat sayısı değişkeninin model performansına en yüksek katkıyı sağladığını ($\Delta\text{BalAcc} = 0.413 \pm 0.022$) göstermektedir. Bunu sırasıyla yapım yılı ($\Delta\text{BalAcc} = 0.370 \pm 0.022$), depremin yer ivmesi göstergesi olan PGA ($\Delta\text{BalAcc} \approx 0.34$) ve faylara olan en kısa yatay uzaklığı temsil eden Rjb ($\Delta\text{BalAcc} \approx 0.32$) izlemektedir. Bu bulgular, bina yüksekliği, yapı yaşı ve yer hareketi ivmesi gibi parametrelerin hasar sınıflarının ayırt edilmesinde belirleyici olduğunu ortaya koymaktadır.

Zemin büyütme katsayısı ve yapı nizamı değişkenlerinin katkısı orta düzeyde kalırken, taşıyıcı sistem değişkeninin model performansına olan katkısının oldukça sınırlı olduğu görülmektedir ($\Delta\text{BalAcc} \approx 0.005$). Bu durum, çalışma alanındaki yapı stokunun büyük ölçüde betonarme yapılardan oluşması nedeniyle taşıyıcı sistem değişkeninin düşük varyansa sahip olmasıyla açıklanabilir. Dolayısıyla model, ayrıştırıcı gücü daha yüksek ve değişkenliği fazla olan parametrelere ağırlık vermiştir.

Genel olarak değişken önem dağılımı, modelin deprem mühendisliği açısından beklenen fiziksel ilişkilerle uyumlu biçimde davrandığını ve elde edilen sonuçların veri bağlamı ile tutarlı olduğunu göstermektedir.

5. DEĞERLENDİRME VE YORUM

Bu çalışmada elde edilen bulgular, bina ölçeğinde deprem sonrası hasar tahmininde makine öğrenmesi yöntemlerinin etkinliğinin, yalnızca seçilen algoritmaya değil; veri yapısına, değerlendirme yaklaşımına ve kullanılan performans ölçütlerine güçlü biçimde bağlı olduğunu ortaya koymaktadır. Özellikle aşırı dengesiz sınıf dağılımına sahip gerçek hasar verilerinde, tekil doğruluk ölçütlerine dayalı değerlendirmelerin yanıltıcı olabileceği; buna karşılık sınıf-duyarlı metriklerin birlikte ele alınmasının daha güvenilir bir karşılaştırma çerçevesi sunduğu açıkça görülmüştür.

Çalışma sonuçları, boosting ve ensemble tabanlı modellerin, gerçek deprem sonrası hasar verileri gibi heterojen ve dengesiz veri yapılarında daha kararlı ve genellebilir performanslar

üretebildiğini göstermektedir. XGBoost ve Random Forest modellerinin, hem baskın düşük hasar sınıfını doğru biçimde temsil edebilmesi hem de orta ve yüksek hasar sınıflarında kabul edilebilir ayırt edicilik sunması, bu algoritmaların bina hasar tahmini gibi karmaşık problemlerde öne çıkmasını sağlamıştır. Buna karşılık, tek ağaç tabanlı ve parametrik modellere dayalı yaklaşımların, sınıf bazlı genelleme kabiliyetinin sınırlı kaldığı gözlemlenmiştir.

Örnekleme yöntemlerinin etkileri değerlendirildiğinde, Random Over Sampling ve SMOTE'un model performansını otomatik olarak iyileştiren evrensel çözümler olmadığı görülmektedir. Bazı model konfigürasyonlarında dengeli doğruluk değerleri artmış olsa da, bu artış her zaman sınıf bazlı tutarlılığa veya daha yüksek genellebilirliğe karşılık gelmemiştir. Bu durum, örnekleme stratejilerinin model türü ve karar mekanizmasıyla birlikte değerlendirilmesi gerektiğini ve dengesiz veri probleminin tek başına veri artırma yöntemleriyle çözülemeyeceğini göstermektedir.

Değişken önem analizleri, yer hareketi ivmesi ve zemin koşullarının bina hasar düzeyinin belirlenmesinde baskın rol oynadığını; yapısal parametrelerin ise veri seti bağlamında daha sınırlı bir ayırt edici güce sahip olduğunu ortaya koymuştur. Bu sonuç, yapısal değişkenlerin mühendislik açısından önemsiz olduğu şeklinde yorumlanmamalı; aksine, çalışma alanındaki yapı stokunun büyük ölçüde benzer taşıyıcı sistemlere sahip olmasının değişken varyansını sınırladığı göz önünde bulundurulmalıdır. Dolayısıyla değişken önem sonuçlarının, veri bağlamı dikkate alınarak yorumlanması gerekmektedir.

Makine öğrenmesi modellerinin başarımı yalnızca özet performans metrikleri üzerinden değil, aynı zamanda bina bazlı gerçek hasar verileri ile doğrudan karşılaştırma yoluyla da değerlendirilmiştir. Bu kapsamda, XGBoost (Baseline) modeli tarafından üretilen hasar tahminleri, deprem sonrası saha gözlemlerine dayalı gerçek hasar sınıfları ile bina ölçeğinde eşleştirilmiştir.

Elde edilen karşılaştırma sonuçları, modelin özellikle karar destek açısından kritik öneme sahip yüksek hasar sınıfını ayırt etme konusunda yüksek bir başarı sergilediğini göstermektedir. Toplam 202 yüksek hasarlı binanın 197'sinin doğru biçimde sınıflandırılması, modelin riskli yapıların belirlenmesinde güçlü bir ayırt ediciliğe sahip olduğunu ortaya koymaktadır. Orta hasar sınıfında gözlenen sınırlı düzeydeki karışma ise, bu sınıfın saha hasar tespitlerinde doğası gereği daha belirsiz ve geçişli bir karaktere sahip olmasıyla uyumludur.

Baskın düşük hasar sınıfının tümüyle doğru sınıflandırılması, modelin genel doğruluk değerlerini yükseltmekle birlikte, bu çalışmada performans değerlendirmesi yalnızca accuracy metriğine dayandırılmamış; Balanced Accuracy, Macro F1 ve Cohen's Kappa gibi sınıf-duyarlı ölçütler esas alınmıştır. Bu yaklaşım, özellikle aşırı dengesiz veri yapılarında model performansının daha gerçekçi biçimde yorumlanmasına olanak sağlamıştır.

Model çıktılarının CBS ortamında mekânsal olarak görselleştirilmesiyle elde edilen hasar kestirim haritası, yüksek hasar sınıfının zayıf zemin koşulları, yüksek zemin büyütme değerleri ve eski yapı stokunun yoğunlaştığı

alanlarda kümelenmiş olduğunu göstermiştir. Bu mekânsal desenler, gerçek deprem sonrası hasar dağılımlarıyla yüksek düzeyde örtüşmekte olup, model sonuçlarının mühendislik beklentileriyle tutarlı olduğunu ortaya koymaktadır.

Genel olarak bu çalışma, gerçek deprem sonrası hasar verilerine dayalı makine öğrenmesi uygulamalarında, model seçiminden performans ölçütlerine, veri dengeleme stratejilerinden mekânsal yorumlamaya kadar uzanan bütüncül bir değerlendirme yaklaşımının gerekliliğini ortaya koymaktadır. Elde edilen sonuçlar, bina ölçeğinde hasar kestiriminin, yalnızca algoritmik bir problem değil; veri kalitesi, sınıf yapısı ve mühendislik bilgisiyle birlikte ele alınması gereken çok boyutlu bir süreç olduğunu göstermektedir.

6. SONUÇ VE ÖNERİLER

Bu çalışmada, 30 Ekim 2020 Sisam (Seferihisar-İzmir) Depremi sonrasında Bayraklı ve Bornova ilçelerinde gözlenen bina hasar sınıfları, gerçek saha gözlemlerine dayalı veriler kullanılarak makine öğrenmesi yöntemleriyle tahmin edilmiştir. Aşırı dengesiz sınıf dağılımına sahip bina hasar verileri üzerinden farklı algoritmalar karşılaştırılmış; model performansları sınıf-duyarlı ölçütler aracılığıyla değerlendirilmiş ve en başarılı modelin çıktıları Coğrafi Bilgi Sistemleri (CBS) ortamında mekânsal olarak görselleştirilmiştir.

Elde edilen bulgular, ensemble ve boosting tabanlı yaklaşımların, özellikle XGBoost ve Random Forest modellerinin, gerçek deprem sonrası hasar verileri gibi heterojen ve dengesiz veri yapılarında daha dengeli ve kararlı performanslar sunduğunu göstermektedir. Bu modeller, yalnızca baskın düşük hasar sınıfını değil, karar destek açısından kritik öneme sahip orta ve yüksek hasar sınıflarını da ayırt edebilme kapasitesi sergilemiştir. Buna karşılık, tek ağaç tabanlı veya daha parametrik modellere dayalı yaklaşımların, azınlık sınıflarındaki ayırt ediciliğinin sınırlı kaldığı gözlenmiştir.

Çalışma kapsamında uygulanan Random Over Sampling ve SMOTE yöntemlerinin, model performansını her durumda anlamlı biçimde iyileştiren evrensel çözümler olmadığı ortaya konmuştur. Örnekleme stratejilerinin etkisinin; kullanılan

algoritma, karar mekanizması ve performans ölçütleriyle birlikte değerlendirilmesi gerektiği görülmüştür. Bu bulgu, dengesiz veri problemlerinde veri artırma yaklaşımlarının bağlamsal ve dikkatli biçimde ele alınmasının önemini vurgulamaktadır.

En iyi performansı sağlayan model kullanılarak üretilen bina ölçekli mekânsal hasar kestirim haritası, yüksek hasar sınıfının zayıf zemin koşulları, yüksek zemin büyütme değerleri ve eski yapı stokunun yoğunlaştığı alanlarda kümelenmiş olduğunu göstermiştir. Bu mekânsal örüntü, model çıktılarının deprem mühendisliği beklentileriyle uyumlu olduğunu ve CBS ile bütünlük makine öğrenmesi yaklaşımlarının afet risk yönetimi açısından anlamlı karar destek ürünleri sunabileceğini ortaya koymaktadır.

Değişken önem analizleri, bina hasar düzeyinin belirlenmesinde kat sayısı, yapım yılı ve yer hareketi parametrelerinin (PGA, Rjb) baskın rol oynadığını; buna karşılık taşıyıcı sistem gibi değişkenlerin, çalışma alanındaki yapı stokunun görece homojen yapısı nedeniyle sınırlı bir ayırt edici güce sahip olduğunu göstermiştir. Bu durum, elde edilen sonuçların veri bağlamı ve yerel yapı karakteristiği dikkate alınarak yorumlanması gerektiğine işaret etmektedir.

Bu çalışmanın bazı sınırlılıkları bulunmaktadır. Kullanılan hasar verileri, yalnızca meydana gelen deprem koşullarını yansıtmakta olup, farklı senaryo depremlerine doğrudan genelleştirilemez. Ayrıca hasar sınıflarının saha tespitlerine dayalı olması, gözlem belirsizliklerini tamamen ortadan kaldırmamaktadır. Bununla birlikte, veri setinin büyüklüğü, gerçekliği ve bina ölçeğindeki ayrıntı düzeyi, çalışmanın uygulama odaklı değerini güçlendirmektedir.

Gelecekte yapılacak çalışmalarda, farklı deprem senaryoları için yer hareketi parametrelerinin entegrasyonunun yanı sıra, yapım yılı bilgisinin ötesine geçerek bakım durumu, güçlendirme geçmişi ve malzeme bozunumu gibi zamanla değişen yapı özelliklerini temsil edebilecek değişkenlerin modele dâhil edilmesi önerilmektedir. Bu tür zaman bağımlı yapı yaşlanma etkilerinin dikkate alınması, özellikle aynı yapı stokunun uzun dönemli sismik davranışının daha gerçekçi biçimde değerlendirilmesine katkı sağlayacaktır.

TEŞEKKÜR

Bu çalışmanın gerçekleşmesi için veri paylaşımını sağlayan AFAD Başkanlığına ve İzmir Büyükşehir Belediyesine teşekkür ederiz.

KAYNAKLAR

AFAD, 2022. 30 Ekim 2020 İzmir Depremi Hasar Tespit Verileri AYDES, Resmi yazı ile temin edilen kurum verisi.

AFAD, 2023. 06 Şubat 2023 Pazarcık-Elbistan Kahramanmaraş (Mw: 7.7– Mw: 7.6) Depremleri Raporu, T.C. İçişleri Bakanlığı Afet ve Acil Durum Yönetimi Başkanlığı, Erişim adresi: https://deprem.afad.gov.tr/assets/pdf/Kahramanmara%C5%9F%20Depremi%20%20Raporu_02.06.2023.pdf

Aktuğ B., Tiryakioğlu İ., Sözbilir H., Özener H., Özkaymak Ç., Yiğit C.O., Solak H.İ., Eyübagil E.E., Gelin B., Tatar O., Softa M., 2021. GPS derived finite source mechanism of the 30 October 2020 Samos earthquake Mw 6.9 in the Aegean extensional region, Turkish Journal of Earth Sciences, 30(8), 718-737.

Breiman L., 2001. Random forests, Machine Learning, 45(1), 5-32.

- Chawla N.V., Bowyer K.W., Hall L.O., Kegelmeyer W.P., 2002. SMOTE Synthetic minority over sampling technique, *Journal of Artificial Intelligence Research*, 16, 321-357.
- Chen T., Guestrin C., 2016. XGBoost A scalable tree boosting system, *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, 785-794.
- Cortes C., Vapnik V., 1995. Support vector networks, *Machine Learning*, 20(3), 273-297.
- Çetin K.O., Ozan C., Koyuncu A., 2021. 30 Ekim 2020 İzmir Depremi'nin jeoteknik değerlendirmesi, *Jeoloji Mühendisliği Dergisi*, 45(2), 115-132.
- Erdik M., 2013. Earthquake risk in Turkey, *Seismological Research Letters*, 84(6), 1007-1019.
- FEMA, 2012. Multi hazard loss estimation methodology earthquake model HAZUS MH technical manual, Federal Emergency Management Agency, Washington D.C., 712 p.
- Fernandez A., Garcia S., Galar M., Prati R.C., Krawczyk B., Herrera F., 2018. Learning from imbalanced data sets, Springer International Publishing, Cham, Switzerland, 347 p.
- He H., Garcia E.A., 2009. Learning from imbalanced data, *IEEE Transactions on Knowledge and Data Engineering*, 21(9), 1263-1284.
- İzmir Büyükşehir Belediyesi, 2024. Bina Kimlik Belgesi Veri Seti, Erişim adresi: <https://acikveri.bizizmir.com/dataset/bina-kimlik-belgesi>
- Joyner W.B., Boore D.M., 1981. Peak horizontal acceleration and velocity from strong-motion records including records from the 1979 Imperial Valley, California, earthquake. *Bulletin of the Seismological Society of America*, 71:2011-2038.
- Kappos A.J., Panagopoulos G., Panagiotopoulos C., 2006. A hybrid method for the vulnerability assessment of R C and URM buildings, *Bulletin of Earthquake Engineering*, 4, 391-413.
- Khosravani H., Rezaeian A., Motamedi M., 2021. Machine learning based vulnerability assessment of buildings under seismic excitation, *Engineering Structures*, 244, 112821.
- Onat E., İlki A., Yakut A., 2022. Earthquake damage prediction of reinforced concrete buildings using machine learning algorithms, *Bulletin of Earthquake Engineering*, 20(12), 12345-12367.
- Quinlan J.R., 1993. C4.5 Programs for machine learning, Morgan Kaufmann Publishers, San Mateo, CA, USA, 302 p.
- Rumelhart D.E., Hinton G.E., Williams R.J., 1986. Learning representations by back propagating errors, *Nature*, 323(6088), 533-536.
- Sengör A.M.C., Tüysüz O., İmren C., Sakıncı M., Eyidoğan H., Görür N., Le Pichon X., Rangin C., 2014. The North Anatolian Fault A new look, *Annual Review of Earth and Planetary Sciences*, 32, 37-64.
- Seyitoğlu G., Aktuğ B., Esat K., Kaypak B., 2022. Neotectonics of Turkey and surrounding regions A new perspective with block modelling, *Geologica Acta*, 20, 1-21.
- Sun Y., Wong A.K.C., Kamel M.S., 2009. Classification of imbalanced data A review, *International Journal of Pattern Recognition and Artificial Intelligence*, 23(4), 687-719.
- Xie L., Zhu L., Chen Y., 2020. Machine learning techniques for seismic vulnerability assessment A review, *Earthquake Engineering and Engineering Vibration*, 19(3), 611-632.
- Yılmaz M.T., Akgün H., Erberik A., Gündoğan A.A., Koçkar M., Temiz A., Okalp K., Jaleforouzan A., Şahin G., 2023. Topoğrafik ve Jeolojik Sayısal Veriler Kullanılarak Türkiye Ölçeğinde Tahmini Vs30 Haritasının Cbs Ortamında Üretilmesi, Ulusal Deprem Araştırma Programı (UDAP-Ç-20-01) Proje Sonuç Raporu, Kasım 2023 Ankara, 97s.
- Yılmaz Z., Yıldırım H., 2022. Assessment of seismic vulnerability using random forest and GIS integration A case study for western Türkiye, *Natural Hazards*, 112(2), 1147-1168.
- Zhu L., Wang W., Li H., 2020. Seismic damage prediction of buildings based on artificial neural networks, *Soil Dynamics and Earthquake Engineering*, 136, 106206.

ARAŞTIRMA VERİSİ (*Research Data*)

Çalışma kapsamında kullanılan veriler; 30 Ekim 2020 Sisam (Seferihisar-İzmir) Depremi sonrasında AFAD Bilgi Sistemleri Dairesi Başkanlığı tarafından sağlanan Afet Yönetim Karar Destek Sistemi (AYDES) bina bazlı hasar tespit verileri, AFAD Deprem Dairesi Başkanlığı tarafından yürütülen UDAP-Ç-20-01 kodlu "Topoğrafik ve Jeolojik Sayısal Veriler Kullanılarak Türkiye Ölçeğinde Tahmini Vs30 Haritasının CBS Ortamında Üretilmesi" projesine ait zemin verileri ve İzmir Büyükşehir Belediyesi Açık Veri Portalı üzerinden temin edilen yapı ve zemin envanteri verilerinden oluşmaktadır.

ÇIKAR ÇATIŞMASI / İLİŞKİSİ (*Conflict of Interest / Relationship*)

Araştırma kapsamında herhangi bir kişi ve/veya kurumla çıkar çatışması/ilişkisi bulunmamaktadır.

YAZARLARIN KATKI ORANI BEYANI (*Author Contributions*)

- Çalışmanın tasarlanması (*Designing of the study*): D.Y., B.A.
- Literatür araştırması (*Literature research*): D.Y.
- Saha çalışması, veri temini/derleme (*Fieldwork, collection/ compilation of data*): D.Y.
- Verilerin işlenmesi/analiz edilmesi (*Processing/analysis of data*): D.Y.
- Şekil/Tablo/Yazılım hazırlanması (*Preparation of figures/ tables/software*): D.Y.
- Bulguların yorumlanması (*Interpretation of findings*): D.Y.
- Makale yazımı, düzenleme, kontrol (*Writing, editing and checking of manuscript*): D.Y., B.A.